

Pneumonia Detection from Chest X-Ray Images Using Convolutional Neural Network (CNN) and Stochastic Gradient Descent

Siti Syaharani Khoiriyah¹, Christy Atika Sari², Eko Hari Rachmawanto³, Ajib Susanto⁴

Informatics Engineering, Universitas Dian Nuswantoro

111202315171@mhs.dinus.ac.id¹, christy.atika.sari@dsn.dinus.ac.id², eko.hari@dsn.dinus.ac.id³, ajib.susanto@dsn.dinus.ac.id⁴

Article Info

Article history:

Received 2026-07-25

Revised 2026-08-10

Accepted 2026-10-15

Keyword:

*Convolutional Neural Network,
Pneumonia Detection,
Chest X-Ray,
Medical Image Classification,
Decision-Support Tool.*

ABSTRACT

One of the biggest causes of morbidity and death globally, especially in children and the elderly, is pneumonia, an infectious disease that affects the lungs. In order to improve treatment efficacy and lower the risk of serious consequences, early identification of pneumonia is essential. Convolutional Neural Networks (CNN), a type of artificial intelligence, are used to analyse chest X-ray pictures in order to diagnose pneumonia. The purpose of this work is to use a CNN architecture to divide chest X-ray pictures into two groups. Pneumonia and normal. The Chest X-ray (Pneumonia) dataset, which was acquired via Kaggle, was utilised in this investigation. Resizing the photos to 150×150 pixels, normalising pixel values, augmenting the data, and using class weights to correct class imbalance are all part of the preprocessing step. The CNN model consists of three convolutional layers followed by Batch Normalization, Max Pooling, Flatten, Dense, Dropout, and a Sigmoid output layer. This model was trained using the Stochastic Gradient Descent (SGD) optimizer with a learning rate of 0.0001, momentum of 0.9, and Binary Cross-Entropy as the loss function. The maximum number of training epochs was set to 50, with Early Stopping applied to prevent overfitting. The experimental results show that the proposed CNN model achieved an accuracy of 90% on the test dataset. Furthermore, the model achieved a precision of 90%, a recall of 90%, and an F1-score of 90%, indicating that it is capable of effectively distinguishing between normal chest X-ray images and those showing pneumonia. These findings suggest that the proposed CNN architecture can serve as an effective approach to aid in the early detection of pneumonia based on chest X-ray images.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Pneumonia merupakan salah satu penyakit infeksi pada system pernafasan yang meyerang jaringan paru-paru, khususnya alveolus, sehingga menyebabkan terganggunya proses pertukaran oksigen di dalam tubuh. Penyakit ini dapat disebabkan oleh infeksi bakteri, virus, maupun jamur dengan tingkat keparahan yang bervariasi, mulai dari ringan hingga mengancam jiwa [1]. WHO menyatakan bahwa pneumonia, penyakit menular pada paru-paru manusia, merupakan masalah kesehatan yang serius di Indonesia dan di seluruh dunia. Pada tahun 2017, pneumonia menyumbang sekitar 15% dari seluruh kematian anak di bawah usia lima tahun [2]. Di Indonesia sendiri, pneumonia masih menjadi salah satu penyakit yang banyak ditemukan. Penyakit ini

umumnya menyerang anak-anak berusia dua tahun serta lansia yang berusia 65 tahun keatas [3]. Kekebalan tubuh yang lemah juga memiliki risiko tinggi mengalami pneumonia [4]. Pneumonia disebabkan oleh infeksi bakteri, virus, maupun jamur yang menyerang jaringan paru-paru. Selain pneumonia, terdapat beberapa penyakit lain yang juga menyerang organ paru-paru, seperti penyakit paru obstruktif kronis (PPOK), asma, tuberkulosis (TBC), fibrosis paru, dan kanker paru-paru [2].

Pemeriksaan fisik, tes laboratorium, dan pencitraan medis menggunakan Chest X-Ray (CXR) adalah metode yang biasanya digunakan untuk mendiagnosis pneumonia. Pemeriksaan CXR menjadi metode yang paling banyak digunakan karena relatif cepat, mudah diperoleh, dan memiliki biaya yang lebih rendah dibandingkan metode pencitraan lainnya seperti

CT scan. Namun demikian, interpretasi citra X-Ray masih bergantung pada pengalaman dan ketelitian radiologi, sehingga proses diagnosis dapat memerlukan waktu serta berpotensi menimbulkan variasi hasil antar pemeriksa, terutama Ketika jumlah pasien yang harus ditangani cukup banyak [5]. Jumlah pasien dapat menyebabkan terjadinya kesalahan diagnosis maupun keterlambatan dalam proses identifikasi penyakit [6] Kondisi tersebut mendorong perlunya pengembangan sistem diagnosis otomatis yang mampu membantu tenaga medis dalam mengidentifikasi pneumonia secara lebih cepat, konsisten, dan akurat.

Analisis citra medis telah banyak berubah berkat kemajuan AI, terutama dalam deep learning. Convolutional Neural Network (CNN) karena salah satu metode deep learning yang paling populer karena dapat mengekstrak fitur gambar secara otomatis tanpa memerlukan proses ekstraksi fitur manual. CNN telah terbukti sangat efektif dalam klasifikasi citra medis, seperti klasifikasi penyakit paru-paru menggunakan gambar citra Chest X-Ray [3]. Selain meningkatkan akurasi diagnosis, CNN juga dapat mempercepat proses identifikasi penyakit, membantu pengambilan keputusan klinis [7]. Salah satu tindakan utama untuk mengidentifikasi pneumonia adalah melalui pemeriksaan radiologi seperti citra X-ray paru-paru [8].

Dalam praktik medis, diagnosis pneumonia umumnya dilakukan melalui pemeriksaan radiologi seperti citra pada X-ray atau CT-scan pada paru-paru. Namun, analisis citra secara manual oleh tenaga medis memiliki beberapa keterbatasan, Pemeriksaan tomografi komputasi (CT) menggunakan teknologi sinar-X dan sistem komputer khusus. Tujuannya adalah untuk melihat struktur dalam tubuh dari banyak sudut dan penampang melintang. Energi gelombang radio dan medan magnet dapat digunakan untuk menggambar struktur dan organ tubuh [9]. Kondisi ini dapat menyerang orang dari segala usia, mulai dari anak-anak hingga orang dewasa, dan telah menjadi masalah kesehatan yang besar di seluruh dunia. Prevalensi pneumonia menunjukan kenaikan yang cukup signifikan dan menempati posisi kedua sebagai penyebab kematian balita setelah diare. Tingginya angka kematian ini sering kali diperburuk oleh faktor udara dan kondisi lingkungan yang kurang sehat, terutama dinegara-negara berkembang [10].

Berbagai penelitian sebelumnya telah mengembangkan model CNN dengan arsitektur yang berbeda-beda. Penelitian oleh Mujahid et al. menggunakan metode CNN yang dikombinasikan dengan RGB Histogram Equalization untuk mengklasifikasikan citra X-Ray menjadi empat kelas, yaitu pneumonia, COVID-19, tuberkulosis, dan normal, serta memperoleh akurasi sebesar 91% [3]. Selanjutnya, Mujahid et al. mengembangkan kombinasi Inception-V3 dan CNN yang menghasilkan akurasi hingga 99,29% pada klasifikasi pneumonia berbasis citra X-Ray [4]. Penelitian lain oleh Alshmrani et al. mengusulkan kombinasi VGG19 dan CNN untuk klasifikasi multi-penyakit paru-paru yang meliputi pneumonia, COVID-19, tuberkulosis, kanker paru, dan lung opacity dengan akurasi mencapai 96,48% [11]. Sementara itu,

Akbar et al. melakukan evaluasi terhadap 20 arsitektur CNN dan menunjukkan bahwa EfficientNet-B0 memberikan performa terbaik dengan akurasi 94,13% pada deteksi pneumonia menggunakan citra Chest X-Ray [12].

Meskipun berbagai penelitian telah menunjukkan bahwa klasifikasi pneumonia sangat mudah, sebagian besar penelitian sangat bergantung pada model transfer learning yang telah dilatih sebelumnya (seperti *Inception-V3*, *VGG19*, atau *EfficientNet*). Pendekatan transfer learning sering kali memiliki ukuran model yang besar, kompleksitas komputasi yang tinggi, dan parameter yang kompleks, yang membuatnya kurang efektif pada perangkat yang memiliki sumber daya komputasi yang terbatas. tanpa mengevaluasi implementasi CNN secara langsung pada dataset Chest X-Ray yang digunakan dalam penelitian ini. Selain itu, penelitian sebelumnya jarang menilai kinerja arsitektur CNN custom sederhana yang dirancang secara khusus dan dioptimalkan langsung untuk fitur dataset X-Ray Chest. Oleh karena itu, masih banyak penelitian yang belum dilakukan tentang seberapa baik model arsitektur CNN yang dirancang secara mandiri (custom) dengan dukungan optimizer yang tepat dapat mencapai kinerja yang kompetitif tanpa bergantung pada desain pelatihan yang kompleks. Oleh karena itu, masih diperlukan penelitian yang mengimplementasikan dan mengevaluasi arsitektur CNN pada dataset Chest X-Ray untuk memperoleh model klasifikasi yang memiliki performa baik serta mampu membantu proses diagnosis pneumonia secara otomatis. Dengan mempertimbangkan masalah-masalah tersebut, penelitian ini memilih untuk mengembangkan arsitektur CNN khusus yang terdiri dari tiga lapisan konvolusional. Arsitektur ini dipilih karena memastikan efisiensi komputasi, membuat proses ekstraksi fitur spasial hierarkis dari gambar sinar-X lebih mudah dipahami, dan mengurangi risiko overfitting, yang merupakan masalah umum dengan model yang terlalu dalam (terlalu banyak parameter) saat menangani data medis yang menunjukkan variasi. Studi ini bertujuan untuk menguji stabilitas konvergensi model dalam mengenali pola infiltrat pneumonia dengan menggunakan optimizer Stochastic Gradient Descent (SGD).


Tujuan penelitian ini adalah untuk menciptakan arsitektur Convolutional Neural Network (CNN) yang dapat digunakan untuk mendeteksi pneumonia menggunakan gambar rontgen dada digital. Diharapkan model yang dikembangkan dapat mengklasifikasikan gambar secara otomatis dengan sangat akurat, membantu para tenaga medis membuat keputusan (*computer-aided diagnosis*). Studi sebelumnya menunjukkan bahwa berbagai pendekatan menghasilkan berbagai tingkat akurasi. Metode Convolutional Neural Network yang telah digunakan sebelumnya oleh para peneliti di bidang ini akan diterapkan dalam penelitian ini. Selain itu, akan ada proses pemrosesan gambar yang menggunakan histogram RGB untuk data gambar rontgen. Tujuan penelitian ini adalah untuk mengetahui tingkat kinerja metode yang digunakan dan apakah hasilnya dapat diterapkan dan digunakan secara efektif.

II. METODE

A. Dataset

Penelitian ini menggunakan dua Kumpulan data public yang ditemukan di Kaggle yaitu Chest X-Ray Images (*Pneumonia*) yang dipublikasikan oleh Paul Mooney pada link <https://kaggle.com/paultimothymooney/chestxray-pneumonia>. Dataset tersebut dipilih karena banyak digunakan sebagai dataset acuan dalam penelitian klasifikasi penyakit paru-paru berbasis deep learning, serta memiliki kualitas citra yang telah melalui proses seleksi oleh tenaga medis. Dataset *Chest X-Ray Images (Pneumonia)* ini berisi 5.863 citra *X-Ray* dada dalam format JPEG yang dibagi menjadi dua kelas, yaitu Normal dan Pneumonia. Gambar-gambar ini diperoleh dari pasien anak berusia 1–5 tahun di Guangzhou Women and Children's Medical Center, Tiongkok. Sebelum digunakan sebagai dataset penelitian, seluruh citra telah melalui proses quality control untuk menghilangkan gambar yang berkualitas rendah, kemudian diverifikasi oleh dua dokter ahli, sedangkan data evaluasi diperiksa kembali oleh dokter ketiga

untuk memastikan ketepatan label yang diberikan. Dataset ini telah disusun ke dalam folder train, validation, dan test, sehingga memudahkan proses pelatihan dan evaluasi model. Untuk memudahkan proses pelatihan, *validasi*, dan pengujian model, struktur dataset dibagi menjadi tiga folder utama: *train*, *validasi (val)*, dan *test*. Folder pelatihan membantu model CNN memahami pola dalam gambar, folder validasi memantau kinerja model selama proses pelatihan dan mencegah *overfitting*, sedangkan folder pengujian mengevaluasi kinerja model pada data yang tidak digunakan selama proses pelatihan. Selama fase implementasi, seluruh dataset dibagi menjadi tiga kelompok. Model Convolutional Neural Konvolusional (CNN) dilatih dengan Data pelatihan, data validasi, dan data pengujian. Data validasi mengawasi kinerja model selama proses pelatihan dan mencegah *overfitting*, sedangkan data uji mengevaluasi kemampuan model untuk mengklasifikasikan gambar yang tidak digunakan selama proses pelatihan.



Gambar 1. Diagram Dataset dalam Pemrosesan

Berdasarkan Gambar 1, diagram dataset dalam Pemrosesan dilakukan melalui beberapa tahapan sebelum data digunakan sebagai masukan (*input*) pada model *Convolutional Neural Network (CNN)*. Penjelasan setiap tahapan sebagai berikut.

1) *Dataset Asli (Chest X-Ray Images)*. Tahap pertama pengumpulan dataset *Chest X-Ray Images (Pneumonia)* yang

diperoleh dari Kaggle. Dataset terdiri atas 5.856 citra digital berformat JPEG yang berbagi menjadi dua kelas, yaitu Normal dan Pneumonia. Seluruh citra merupakan hasil pemeriksaan *Chest X-Ray (AP View)* pada pasien anak berusia 1-5 tahun yang telah melalui proses *validasi* oleh tenaga medis sehingga dapat digunakan sebagai data penelitian sesuai pada Tabel I.


2) *Pembagian Dataset*. Setelah dataset diperoleh, data dibagi menjadi tiga kelompok, yaitu *training*, *validation*, dan *testing*. Data training digunakan untuk melatih model CNN agar mampu mengenali pola pada citra, data *validation* digunakan untuk memantau performa Kumpulan data disusun secara sistematis untuk memungkinkan pelatihan model, yang membantu dalam menentukan model terbaik. Di sisi lain, data pengujian digunakan untuk mengevaluasi kinerja model pada data yang belum pernah digunakan sebelumnya.

3) *Preprocessing Data*. Tahap prapemrosesan dilakukan untuk meningkatkan kualitas sebelum data diproses pada model CNN. Dalam penelitian ini, Langkah-langkah ini termasuk:

- **Resize**, yaitu mengubah ukuran seluruh gambar menjadi 150 x 150 piksel agar semua data memiliki ukuran yang seragam sesuai dengan persyaratan masukan model CNN.
- **Normalisasi**, yaitu mengubah proses nilai piksel 0 hingga 255 menjadi 0-1 menggunakan proses *rescale* 1/255, sehingga proses pelatihan menjadi lebih stabil.

- **Augmentasi Data**, yang hanya berlaku untuk kumpulan data pelatihan (*training set*). Teknik augmentasi meliputi *rotation* sebesar 15°, *zoom* sebesar 20%, *width shift* sebesar 10%, *height shift* sebesar 10%, serta *horizontal flip*. Sehingga model dapat digeneralisasi dengan lebih baik dan tidak mudah mengalami *overfitting*, augmentasi digunakan untuk meningkatkan variasi gambar. Class Weight, yaitu pemberian bobot pada setiap kelas dengan fungsi *compute_class_weight()* digunakan untuk memberi bobot pada setiap kelas. Ini memungkinkan model untuk tidak belajar dari kelas dengan lebih banyak data.

4) *Data Siap Digunakan*. Setelah seluruh proses pre-processing selesai dilakukan, data training, validation, dan testing siap digunakan sebagai masukan pada model CNN. Selama pelatihan model, data validasi digunakan untuk mengevaluasi kinerja model pada epoch, dan pada tahap akhir penelitian, data uji digunakan untuk mengklasifikasi gambar *Chest X-Ray* ke dalam kelas Normal atau pneumonia.



Gambar 2. Samples dataset

TABEL I
KARAKTERISTIK DATASET

Kelas	Penjelasan
Normal	Berisi citra <i>Chest X-Ray</i> paru-paru yang tidak menunjukkan adanya infeksi atau kelainan. Struktur paru-paru tampak bersih, area paru berwarna lebih gelap (<i>radiolusen</i>), dan tidak terlihat <i>infiltrat</i> maupun cairan. Citra pada kelas ini digunakan sebagai acuan kondisi paru-paru yang sehat.

Pneumonia	Berisi citra <i>Chest X-Ray</i> paru-paru yang mengalami infeksi pneumonia. Pada citra biasanya terlihat area berwarna lebih putih (<i>opacity</i> atau <i>infiltrat</i>) akibat adanya penumpukan cairan atau peradangan pada <i>alveolus</i> . Ciri-ciri tersebut digunakan oleh model CNN untuk membedakan citra pneumonia dari citra normal.
-----------	--


Untuk proses evaluasi model, kumpulan data tersebut dibagi menjadi data training, *validation*, dan *testing*. Data validasi digunakan untuk mengawasi kinerja model selama pelatihan, sedangkan data *testing* digunakan untuk mengevaluasi kemampuan model untuk mengklasifikasikan gambar yang tidak digunakan selama pelatihan. Untuk mengurangi efek ketidakseimbangan data selama proses pelatihan model, penelitian ini menggunakan Teknik class weight. Ini karena Tabel II menunjukkan bahwa ada lebih banyak gambar untuk kelas Pneumonia daripada gambar untuk kelas Normal.

TABEL II
PROSENTASE PEMROSESAN DATASET

Nama kelas	Training (80%)	Validasi (10%)	Testing (10%)	Total
Normal	1.341	8	234	1.583
Pneumonia	3.875	8	390	4.273
Total	5.216	16	624	5.856

B. Data Preprocessing

Data preprocessing digunakan dalam model pembelajaran mendalam, pemrosesan data adalah tahap penting dalam pemrosesan gambar. Tahap prapemrosesan melibatkan pembersihan kumpulan data, proses preprocessing melibatkan pembersihan data, perubahan ukuran citra (*resizing*), normalisasi, serta augmentasi data untuk meningkatkan kualitas dan peningkatan dataset [13]. Tujuan Preprocessing adalah untuk meningkatkan kinerja model selama pelatihan dan mengurangi kemungkinan *overfitting* [14]. Kumpulan data penelitian ini terdiri dari gambar rontgen dada yang dikelompokkan ke dalam folder training, validation, dan testing. Seluruh citra dimuat menggunakan fungsi *flow_from_directory()* yang tersedia pada pustaka TensorFlow Keras, sehingga proses pembacaan data dilakukan secara otomatis sesuai dengan label kelas pada masing-masing folder.



Gambar 4. Tahap pra-pemrosesan data gambar X-ray

Tahap pertama dalam preprocessing adalah merubah ukuran citra (*resize*) menjadi 150×150 piksel. Penyeragaman ukuran citra diperlukan agar seluruh data memiliki dimensi yang sama sehingga dapat diproses oleh model CNN secara konsisten. Selain itu, ukuran citra yang lebih kecil mampu mengurangi kebutuhan memori dan mempercepat proses komputasi tanpa menghilangkan informasi penting pada citra Chest X-Ray [12]. Setelah proses *resize*, dilakukan normalisasi nilai piksel menggunakan parameter *rescale = 1/255* pada *ImageDataGenerator*. Proses normalisasi mengubah rentang nilai piksel dari 0–255 menjadi 0–1, sehingga distribusi data menjadi lebih stabil dan proses pembelajaran model

menjadi lebih cepat. Normalisasi juga membantu proses optimasi selama pelatihan karena mengurangi perbedaan skala antar piksel [12]. Untuk meningkatkan kemampuan generalisasi model, penelitian ini menerapkan augmentasi data pada data latih (*training set*) menggunakan *ImageDataGenerator*. Teknik augmentasi yang digunakan meliputi rotation sebesar 15° , zoom sebesar 20%, *width shift* sebesar 10%, *height shift* sebesar 10%, serta *horizontal flip*.

Augmentasi dilakukan dengan menghasilkan variasi citra baru tanpa mengubah informasi utama yang terkandung pada citra asli. Dengan demikian, model memperoleh lebih banyak variasi data selama proses pelatihan sehingga mampu

mengenali pola citra secara lebih baik dan mengurangi kemungkinan terjadinya overfitting [15]. Selain augmentasi data, penelitian ini menggunakan teknik bobot kelas melalui fungsi pustaka *Scikit-learn compute_class_weight()*. Teknik ini digunakan karena jumlah data pada kelas Normal dan Pneumonia tidak seimbang. Pemberian bobot yang berbeda pada setiap kelas bertujuan agar model tidak lebih dominan mempelajari kelas mayoritas, sehingga proses klasifikasi menjadi lebih adil dan menghasilkan performa yang lebih baik pada kedua kelas. Hasil dari seluruh tahapan pre-processing menghasilkan dataset yang telah memiliki ukuran citra yang seragam, nilai piksel yang telah dinormalisasi, variasi data yang lebih beragam melalui augmentasi, serta distribusi kelas yang lebih seimbang melalui penerapan *class weight*. Dataset tersebut kemudian digunakan sebagai masukan pada proses pelatihan model *Convolutional Neural Network* (CNN).

c. Modelling

Fase modeling mencakup pembuatan model *Convolutional Neural Network* (CNN) yang digunakan untuk mengklasifikasi citra *Chest X-Ray* ke dalam dua kelas, yaitu Normal dan Pneumonia. CNN dipilih karena memiliki kemampuan mengekstraksi fitur citra secara otomatis melalui proses konvolusi sehingga sangat sesuai untuk permasalahan klasifikasi citra medis. Arsitektur CNN mampu menganalisis pola spasial dalam gambar secara hierarkis, mulai dari elemen sederhana seperti tepi dan tekstur hingga elemen yang lebih kompleks, sehingga banyak digunakan dalam penelitian tentang bagaimana gambar sinar-X dapat mendeteksi pneumonia [16]. Model CNN pada penelitian ini dibangun menggunakan *TensorFlow Keras* dengan pendekatan *Sequential Model*. Citra masukan (input image) berukuran $150 \times 150 \times 3$ diproses melalui tiga block utama yang masing-masing terdiri atas *Convolutional Layer*, *Batch Normalization*, dan *Max Pooling Layer*.

Kombinasi ketiga lapisan ini dirancang untuk meningkatkan efisiensi perhitungan dengan menghilangkan atribut penting dari gambar, menstabilkan proses pelatihan, dan mengurangi dimensi peta fitur. Pada lapisan konvolusi pertama digunakan 32 filter dengan ukuran kernel 3×3 dan fungsi aktivasi Rectified Linear Unit (ReLU). Selanjutnya lapisan konvolusi kedua menggunakan 64 filter, sedangkan lapisan konvolusi ketiga menggunakan 124 filter dengan ukuran kernel yang sama. Fungsi aktivasi ReLU dipilih karena mampu mempercepat proses pembelajaran model serta mengurangi permasalahan vanishing gradient selama proses pelatihan jaringan saraf [17]. Setelah setiap proses konvolusi diterapkan *Batch Normalization* untuk menjaga distribusi data pada setiap mini-batch tetap stabil sehingga proses pelatihan menjadi lebih cepat dan konvergen. Selanjutnya digunakan *Max Pooling* berukuran 2×2 untuk mengurangi dimensi feature map dengan tetap mempertahankan informasi penting yang telah diekstraksi dari citra. Tahapan konvolusi dan pooling merupakan bagian utama dalam CNN yang berfungsi menghasilkan representasi fitur secara bertahap sebelum dilakukan proses klasifikasi.


Setelah menggunakan Lapisan Flatten, hasil ekstraksi fitur diubah menjadi vektor satu dimensi dan kemudian dimasukkan ke dalam Lapisan Fully Connected. Untuk mengurangi kompleksitas model, penelitian ini menggunakan Lapisan Dense dengan 128 neuron dan fungsi aktivasi ReLU. Ini dikombinasikan dengan regularisasi L2 yang disetel ke 0,005. Selain itu, tingkat dropout sebesar 0,3 digunakan untuk mengurangi risiko overfitting dengan menonaktifkan sejumlah neuron secara acak selama pelatihan. Sebuah penelitian telah menunjukkan bahwa dropout dan regularisasi meningkatkan kemampuan generalisasi model dalam klasifikasi citra medis.

TABEL III
ARSITEKTUR CNN

Tahap	Output Shape
Input	150 x 150 x3
Conv2D	32 -64-128
Dense(128) + L2	0.005
Dropout	0.3
Output Dense	(1,Sigmoid)

Penelitian tahun 2022 oleh Guermazi dkk. telah menemukan bahwa penggunaan lapisan konvolusional dan lapisan pooling dalam CNN meningkatkan kemampuan ekstraksi fitur untuk klasifikasi gambar medis dan membantu mengurangi kompleksitas komputasi selama proses pelatihan [18]. Mengurangi kompleksitas komputasi dengan mengurangi dimensi fitur sambil mempertahankan data penting adalah tujuan penggunaan lapisan pooling [19].

Penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) yang dibangun secara *custom* menggunakan *TensorFlow Keras* untuk mengklasifikasi citra *Chest X-Ray* ke dalam dua kelas, yaitu Normal dan Pneumonia. Pada Gambar 4, tahapan penelitian diawali dengan pengumpulan dataset citra *Chest X-Ray* yang kemudian dibagi menjadi data *training*, *validation*, dan *testing*. Selanjutnya dilakukan tahap prapemrosesan data yang meliputi normalisasi nilai piksel menggunakan *rescale* sebesar $1/255$, augmentasi data pada data latih yang terdiri atas *rotation*, *zoom*, *width shift*, *height shift*, dan *horizontal flip*, serta penerapan *class weight* untuk mengatasi ketidakseimbangan jumlah data pada masing-masing kelas. Setelah proses prapemrosesan selesai, dibangun model CNN yang terdiri atas tiga lapisan *Convolutional*, *Batch Normalization*, *Max Pooling*, *Flatten*, *Dense*, dan *Dropout*. Selanjutnya, untuk menghindari overfitting, model dilatih menggunakan optimizer *Stochastic Gradient Descent* (SGD) dengan laju pembelajaran 0,0001, momentum 0,9, dan *Early Stopping*. Langkah terakhir adalah menilai kinerja model menggunakan data uji. Ini melibatkan menghitung akurasi, presisi, pengembalian, skor F1, laporan klasifikasi, dan matriks kebingungan sebagai indikator kinerja. Metode penelitian yang digunakan.



Gambar 5. Flowchat Alur penelitian

Gambar 5 menunjukkan tahapan umum dalam pengembangan sistem yang menggunakan pembelajaran mesin yang diikuti oleh metodologi penelitian ini. Pembelajaran mesin (ML) adalah jenis kecerdasan buatan yang berkonsentrasi pada pembuatan algoritma yang dapat digunakan untuk mengidentifikasi pola dalam data secara otomatis. Dalam penerapannya di lapangan, pembelajaran mesin mengikuti siklus yang terdiri dari pengumpulan data, prapemrosesan, pemilihan arsitektur, dan evaluasi kinerja, sehingga menghasilkan model yang dapat diandalkan untuk aplikasi di dunia nyata [20]. Klasifikasi citra medis melibatkan sistem yang secara objektif mengekstraksi karakteristik klinis dari citra sinar-X

melalui tahapan pelatihan yang direncanakan untuk mengurangi kesalahan diagnosis [21]. Setiap Langkah dilakukan secara sistematis dan berurutan untuk menghasilkan model klasifikasi citra sinar-X yang akurat dan berguna.

D. Evaluasi

Proses evaluasi melibatkan pengukuran model menggunakan data yang diuji. Confusion Matrix merupakan tabel evaluasi yang digunakan untuk menunjukkan hasil klasifikasi model berdasarkan jumlah prediksi yang benar maupun salah pada masing-masing kelas. Laporan klasifikasi mencakup metrik seperti *accuracy*, *precision*, *recall* dan *F1-score* yang dihitung [22]. Akurasi berfungsi untuk mengukur presentase prediksi yang benar dari seluruh data uji, sesuai persamaan (1). Untuk mengetahui seberapa akurat suatu model memprediksi suatu kelas tertentu, presisinya diukur dengan membandingkan proporsi prediksi positif yang benar dengan jumlah total prediksi positif, yang ditunjukkan dalam persamaan (2). Recall berfungsi untuk mengukur kemampuan model untuk menemukan semua contoh positif sejati dalam data, seperti terlihat pada persamaan (3). Sebagaimana ditunjukkan dalam persamaan, score F-1 digunakan untuk menghitung rata-rata harmonik antara presisi dan recall, ini berfungsi sebagai ukuran keseimbangan kinerja model (4).

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

Dimana :

True Positive (TP) = Jumlah data positif yang berhasil di prediksi benar sebagai positif oleh model.

True Negative (TN) = Jumlah data negatif yang berhasil diprediksi benar sebagai negatif oleh model.

False Positive (FP) = Jumlah data negatif, tetapi diprediksi salah sebagai positif oleh model.

False Negative (FN) = Jumlah data positif, tetapi diprediksi salah sebagai negatif oleh model.

III. HASIL DAN PEMBAHASAN

A. Hyperparameter

Bahasa pemrograman Python digunakan untuk melakukan penelitian ini, dan Google Colaboratory digunakan sebagai lingkungan komputer. Proses pembangunan model memanfaatkan pustaka *TensorFlow*, *Keras*, *NumPy*, *Pandas*, *Matplotlib*, dan *Scikit-learn*. Seluruh proses pelatihan dilakukan menggunakan dataset *Chest X-Ray Images* (Pneumonia) yang diperoleh dari Kaggle. Model arsitektur dibangun menggunakan metode *Convolutional Neural Network* (CNN) dengan *optimizer Stochastic Gradient Descent* (SGD), sedangkan proses *evaluasi* dilakukan menggunakan

Confusion Matrix, Classification Report, Accuracy, Precision, Recall, dan F1-Score. Semua gambar melalui tahapan prapemrosesan sebelum digunakan dalam proses pelatihan. Tahapan ini meliputi *resize* citra menjadi ukuran 150×150 piksel, normalisasi nilai piksel menggunakan *rescale* sebesar $1/255$, serta augmentasi data pada data latih yang terdiri atas *rotation, zoom, width shift, height shift, dan horizontal flip*. Selain itu, penelitian ini juga menerapkan metode *class weight* untuk mengatasi ketidakseimbangan jumlah data antara kelas Normal dan Pneumonia, sehingga proses pelatihan model menjadi lebih seimbang. Program ini dijalankan di lingkungan Google Colaboratory (Google Colab) menggunakan bahasa pemrograman Python, dan beberapa pustaka pendukung digunakan, antara lain TensorFlow, Keras, NumPy, Pandas, Matplotlib, dan Scikit-learn. Seluruh proses, mulai dari pemuatan dataset, tahap preprocessing, pembangunan arsitektur CNN, proses pelatihan (training), hingga evaluasi model dilakukan pada platform tersebut. Hasil implementasi program menghasilkan sebuah model CNN yang selanjutnya dievaluasi menggunakan data testing. Evaluasi dilakukan dengan menghitung nilai *Accuracy, Precision, Recall, F1-Score, Classification Report, dan Confusion Matrix* untuk mengetahui kemampuan model untuk mengklasifikasikan gambar rontgen dada ke dalam kelas Normal dan Pneumonia, dengan menjelaskan hasil penerapan program pada setiap tahap.

```

Arsitektur CNN, Training, dan Evaluasi.py > ...
18 train_datagen = ImageDataGenerator(
19     rescale=1./255,
20     rotation_range=15,
21     zoom_range=0.2,
22     width_shift_range=0.1,
23     height_shift_range=0.1,
24     horizontal_flip=True
25 )
26
27 val_test_datagen = ImageDataGenerator(rescale=1./255)
28
29 BATCH_SIZE = 32
30 IMAGE_SIZE = (150, 150)
31
32 print("[*] Memuat Data Train...")
33 train_generator = train_datagen.flow_from_directory(
34     'train',
35     target_size=IMAGE_SIZE,
36     batch_size=BATCH_SIZE,
37     class_mode='binary'
38 )
39
40 print("\n[*] Memuat Data Validation...")
41 val_generator = val_test_datagen.flow_from_directory(
42     'val',
43     target_size=IMAGE_SIZE,
44     batch_size=BATCH_SIZE,
45     class_mode='binary'
46 )
47
48 print("\n[*] Memuat Data Test...")
49 test_generator = val_test_datagen.flow_from_directory(
50     'test',
51     target_size=IMAGE_SIZE,
52     batch_size=BATCH_SIZE,
53     class_mode='binary',
54     shuffle=False

```

Gambar 6. Code preprocessing & Data Loader

Pengujian sistem dilakukan selama pelaksanaan sistem untuk memastikan keakuratan sistem dalam mendeteksi pneumonia atau non-pneumonia pada gambar rontgen paru-paru. Salah satu pertimbangan dalam pengembangan sistem ini adalah bahwa selama proses pelatihan, hiperparameter harus digunakan, sesuai dengan parameter yang tercantum dalam Tabel IV, untuk mendapatkan hasil yang baik dari pengujian sistem.

Berdasarkan Tabel IV, model yang dibangun pada penelitian ini menggunakan arsitektur Convolutional Neural Network (CNN) untuk mengklasifikasikan citra Chest X-Ray ke dalam dua kelas, yaitu Normal dan Pneumonia. Seluruh citra masukan (input image) diubah ukurannya menjadi $150 \times 150 \times 3$ piksel agar memiliki dimensi yang seragam sebelum diproses oleh model. Proses pelatihan dilakukan dengan jumlah maksimum 50 epoch dan batch size sebesar 32. Pada setiap epoch, data pelatihan dibagi menjadi beberapa batch sehingga model dapat memperbarui bobot jaringan secara bertahap. Berdasarkan jumlah data pelatihan sebanyak 5.216 citra, diperoleh 163 iterasi pada setiap epoch. Selama proses pelatihan, validasi dilakukan pada akhir setiap interval untuk mengetahui seberapa baik kinerja model dengan data validasi. Algoritma optimisasi Stochastic Gradient Descent (SGD), yang memiliki laju pembelajaran 0,0001 dan momentum 0,9, digunakan untuk model ini. Kombinasi parameter tersebut dipilih untuk membantu model mencapai proses konvergensi yang lebih stabil serta mengurangi kemungkinan terjebak pada nilai minimum lokal selama proses optimasi. Pada setiap lapisan tersembunyi, fungsi aktivasi ReLU (Rectified Linear Unit) dapat mempercepat proses pembelajaran dan mengurangi masalah gradien yang menghilang. Karena studi ini menggunakan klasifikasi biner, yang menghasilkan kemungkinan untuk kelas Normal dan Pneumonia, lapisan keluaran menggunakan fungsi aktivasi Sigmoid.

TABEL IV
PARAMETER PELATIHAN MODEL CNN

Parameter	Nilai
Arsitektur Model	Convolutional Neural Network (CNN)
Input Image Size	150 x 150 x 3
Jumlah Kelas	2 (Normal dan Pneumonia)
Epoch	50
Batch Size	32
Optimizer	Stochastic Gradient Descent (SGD)
Learning Rate	0,0001
Momentum	0,9
Loss Function	Binary Crossentropy
Activation Function	ReLU (Hidden Layer), Sigmoid (Output Layer)
Dropout	0,3
L2 Regularization	0,005
Batch Normalization	Ya
Early Stopping	Monitor = Validation Loss, Patience = 5
Validation Frequency	Setiap 1 Epoch
Accuracy	90%
Total Data Training	5.216 Citra
Total Data Validation	16 Citra
Total Data Testing	624 Citra
Total Iterasi per Epoch	163 Iterasi

Untuk mengurangi risiko overfitting, model menerapkan beberapa teknik regularisasi, yaitu Batch Normalization, Dropout sebesar 0,3, serta L2 Regularization sebesar 0,005. Selain itu, metode penundaan dini digunakan dengan parameter monitor = kehilangan validasi dan ketekunan = 5. Dengan demikian, proses pelatihan akan berhenti secara otomatis jika nilai kehilangan validasi tidak meningkat selama lima epoch berturut-turut. Teknik ini bertujuan untuk menjaga agar model tidak terlalu dilatih dan mempertahankan kemampuan untuk generalisasi terhadap data baru. Hasil evaluasi dengan 624 titik data uji menunjukkan bahwa model ini mencapai akurasi sebesar 90% dalam mengklasifikasikan gambar rontgen dada ke dalam kategori Normal dan Pneumonia dengan kinerja yang baik. Nilai akurasi tersebut menunjukkan bahwa kombinasi parameter pelatihan yang digunakan mampu menghasilkan model CNN yang efektif untuk melakukan identifikasi penyakit pneumonia berdasarkan citra X-Ray.

B. Hasil Evaluasi Model

Setelah pelatihan model selesai, Langkah selanjutnya adalah menguji dengan data uji. Pengujian ini bertujuan untuk mengetahui kemampuan model Convolutional Neural Network (CNN) dalam mengklasifikasikan citra Chest X-Ray dibagi menjadi dua kategori: normal dan pneumonia. Data uji dari penelitian ini terdiri dari 624 foto, terdiri dari 234 foto kelas normal dan 390 foto kelas pneumonia. Semua data yang diuji belum pernah digunakan selama proses pelatihan atau validasi. Hasil uji ini menunjukkan kemampuan model untuk mengklasifikasikan data baru. Tabel V menunjukkan jumlah kasus pneumonia yang diidentifikasi secara akurat dan secara salah, serta sebaliknya. Identifikasi dilakukan dengan melihat nilai persentase tertinggi dari hasil eksperimen; ini menentukan apakah gambar sinar-X yang dimasukkan adalah pneumonia atau non-pneumonia.

TABEL V
CONFUSION MATRIX HASIL PENGUJIAN MODEL

Kelas	Prediksi Normal	Prediksi Pneumonia
Aktual Normal	206 (True Negative)	28 (False Positive)
Aktual Pneumonia	36 (False Negative)	354 (True Positive)

TABEL VI
HASIL PENGUJIAN PERFORMA MODEL BERDASARKAN METRIK EVALUASI

Kelas	Precision	Recall	F1-Score
Normal	86%	88%	87%
Pneumonia	92%	91%	92%
Accuracy Model	90%	89%	89,87


Tingkat Recall (atau Sensitivitas) sebesar 90% untuk kelas Pneumonia ditunjukkan oleh model ini, Seperti yang ditunjukkan dalam Tabel VI. Dalam konteks medis, angka-angka ini sangat penting untuk mengurangi hasil negatif palsu yang terjadi ketika pasien dengan pneumonia yang salah dianggap normal. Ini karena efek klinis dari diagnosis pneumonia yang terlewatkan jauh lebih berbahaya bagi kesehatan pasien. Selain itu, model ini mampu secara efektif membedakan antara kasus sehat dan terinfeksi, menurut metrik Spesifisitas (88% untuk kelas pneumonia) dan nilai Akurasi keseluruhan

(90%). Selain itu, nilai yang tinggi ditunjukkan dalam evaluasi kurva AUC-ROC (Area Under the Receiver Operating Characteristic) yang diuji pada sistem ini. Ini menunjukkan bahwa kemampuan diskriminatif model ini termasuk dalam kategori sangat baik, atau kemampuan klasifikasi yang baik.


C. Analisis Kurva Pelatihan (Training-Validation Curves)

Hasil tersebut menunjukkan jumlah data untuk masing-masing kelas berbeda, model ini menunjukkan kinerja yang seimbang dalam mengidentifikasi kedua kelas tersebut. Tabel VI di atas menunjukkan hasil pelatihan untuk dataset pengujian dan pelatihan dengan 50 epoch. Ditunjukkan bahwa untuk dataset pelatihan dan validasi, setiap iterasi menghasilkan nilai akurasi dan nilai kehilangan. Nilai akurasi berfungsi sebagai tolok ukur untuk menilai keberhasilan atau kesesuaian model yang dikembangkan, sedangkan nilai kehilangan mengukur kegagalan atau kesalahan. Dengan laju pembelajaran 0,0001 dan ukuran batch 32, optimizer Stochastic Gradient Descent (SGD) digunakan untuk melakukan pelatihan model Convolutional Neural Network (CNN) hingga 50 epoch.

Model mempelajari pola dalam data pelatihan dan melakukan validasi pada setiap epoch selama proses pelatihan untuk mengamati perkembangan kinerja model dan mengurangi risiko overfitting dengan menerapkan early stopping, batch normalization, dropout, dan regulasi L2. Berdasarkan grafik Model Accuracy (Gambar 7) dan Model Loss (Gambar 8), nilai training accuracy terus meningkat secara bertahap hingga stabil, sementara training loss menurun secara konsisten. Meskipun kurva validasi sempat mengalami fluktuasi, penerapan teknik Batch Normalization, Dropout (0,3), regularisasi L2 (0,005), serta Early Stopping (dengan patience = 5) terbukti efektif dalam meredam potensi overfitting yang parah. Model mampu mempertahankan kemampuan generalisasi yang baik saat diuji menggunakan data pengujian eksternal di akhir pelatihan.



Gambar 7. Grafik Accuracy (Model Accuracy)



Gambar 8. Grafik Loss (Model Loss)

Grafik tersebut menunjukkan bahwa nilai kehilangan pelatihan menurun secara bertahap setiap waktu, menunjukkan bahwa model CNN memiliki kemampuan untuk mempelajari pola dalam data pelatihan. Di sisi lain, nilai kehilangan validasi terus berubah secara signifikan sepanjang proses pelatihan. Hal ini menunjukkan kemungkinan overfitting dan menunjukkan bahwa kinerja model pada data validasi belum sepenuhnya stabil. Meskipun demikian, penerapan *Batch Normalization*, *Dropout*, *L2 Regularization*, dan *Early Stopping* membantu mengurangi risiko overfitting sehingga model tetap mampu menghasilkan performa klasifikasi yang baik dengan akurasi sebesar 90% pada data pengujian.

Pada kelas Normal, Untuk kelas paru-paru pneumonia, model tersebut mencapai presisi sebesar 0,86, recall sebesar 0,88, dan skor F1 sebesar 0,87, menunjukkan bahwa model tersebut berhasil mengidentifikasi sebagian besar gambar paru-paru normal, meskipun masih ada beberapa gambar normal yang salah diklasifikasikan sebagai pneumonia. Nilai ini lebih tinggi dibandingkan kelas Normal, yang menunjukkan bahwa model memiliki kemampuan yang lebih baik dalam mengenali pola citra pneumonia. Hal ini kemungkinan dipengaruhi oleh jumlah data pneumonia yang lebih banyak pada dataset pelatihan sehingga model memperoleh lebih banyak contoh selama proses pembelajaran.

Kinerja model pada kedua kelas tersebut, tanpa memperhitungkan jumlah data yang ada di dalamnya, ditunjukkan dengan nilai rata-rata makro sebesar 0,89. Sementara itu, weighted average sebesar 0,90 menunjukkan rata-rata performa yang telah mempertimbangkan proporsi jumlah data pada masing-masing kelas. Hasil tersebut mengindikasikan bahwa model memiliki performa yang konsisten dalam melakukan klasifikasi citra *Chest X-Ray*. Secara keseluruhan, model CNN yang dibangun pada penelitian ini telah mampu mengidentifikasi penyakit pneumonia dengan performa yang baik. Penerapan tahap preprocessing, seperti normalisasi, augmentasi data, serta penggunaan class weight, turut berkontribusi dalam meningkatkan kemampuan model untuk melakukan klasifikasi pada kedua kelas.

D. Keterbatasan Penelitian

Penelitian ini memiliki beberapa keterbatasan penting yang perlu diperhatikan untuk pengembangan dimasa mendatang model *Convolutional Neural Network* (CNN) khusus yang diusulkan menunjukkan kinerja klasifikasi yang baik dalam mendeteksi pneumonia dan gambar CT scan:

- Bias Dataset publik: Penelitian ini menggunakan kumpulan data publik sekunder Kaggle. Bias seleksi, distribusi demografis pasien yang tidak merata, dan fitur pemindai rumah sakit tertentu dapat menyebabkan hasil penelitian ini tidak sepenuhnya mewakili populasi global.
- Variasi Kualitas Gambar: Variasi kualitas gambar rontgen dada dapat memengaruhi stabilitas ekstraksi fitur oleh model. Ini dapat termasuk perbedaan tingkat kontras, posisi pasien (posteroanterior atau anteroposterior), dan adanya artefak eksternal.
- Kurangnya Validasi Klinis Langsung: Model ini tidak diuji secara langsung dalam alur kerja klinis dunia nyata (validasi klinis dunia nyata) atau divalidasi langsung oleh radiolog. Sebaliknya, evaluasi komputasional hanya menggunakan metrik kuantitatif (akurasi, presisi, recall, spesifisitas, dan AUC-ROC) pada data uji.

V. KESIMPULAN

Studi ini menemukan pneumonia melalui gambar rontgen dada dengan menggunakan teknik *Convolutional Neural Network* (CNN). Model ini dibangun dengan tiga lapisan konvolusional yang dipadukan dengan normalisasi batch, pengumpulan maksimum, pengurangan, dan regularisasi L2, yang memungkinkan model untuk mengklasifikasikan antara dua kelas, yaitu normal dan pneumonia. Proses pra-pemrosesan, yang mencakup penerapan bobot kelas, augmentasi data, normalisasi nilai piksel, dan pengubahan ukuran gambar menjadi 150 x 150 piksel, berdampak positif pada proses pelatihan model. Metode ini mengurangi kemungkinan overfitting dan membantu model mempelajari karakteristik gambar secara lebih efektif. Hasil pengujian yang menggunakan 624 titik data menunjukkan bahwa model CNN memiliki skor F1 sebesar 90%, akurasi sebesar 90%, presisi sebesar 90%, dan recall sebesar 90%. Hasil ini menunjukkan bahwa model tersebut sangat mampu membedakan antara gambar paru-paru normal dan yang menunjukkan pneumonia. Dengan menggunakan *Early Stopping* dan optimizer *Stochastic Gradient Descent* (SGD) dengan laju pembelajaran 0,0001 dan momentum 0,9, proses pelatihan stabil dan model dengan kinerja klasifikasi yang baik pada data uji.

Model CNN yang diusulkan ini mampu menghasilkan hasil klasifikasi berkinerja tinggi dan transparan yang secara akurat membedakan antara paru-paru normal dan kasus pneumonia, menurut pengujian kuantitatif yang menggunakan 624 titik data uji independen. Model ini dianggap memiliki keandalan klinis yang signifikan dalam mengurangi kesalahan deteksi false-negative karena tingkat recall optimal untuk kelas pneumonia. Oleh karena itu, sistem yang dikembangkan ini tidak dimaksudkan untuk berfungsi sebagai alat diagnostik sendiri.

Sebaliknya, itu dimaksudkan untuk membantu tenaga medis dalam mempercepat proses skrining awal kesehatan paru-paru pasien dengan memberikan dukungan yang dapat diandalkan dan objektif. Agar model dapat mempelajari karakteristik gambar pneumonia secara lebih efektif dan meningkatkan kemampuan generalisasinya, penelitian selanjutnya dapat memanfaatkan kumpulan data yang lebih besar dan lebih beragam. Penelitian di masa mendatang dapat memilih metode transfer learning seperti MobileNetV2, ResNet50, DenseNet121, dan EfficientNet untuk membandingkan kinerja CNN. Eksperimen dengan berbagai kombinasi laju pembelajaran, ukuran batch, epoch, dan jumlah filter konvolusional dapat meningkatkan proses optimasi model. banyak metode augmentasi data untuk mencapai kinerja model terbaik. Penelitian lebih lanjut juga dapat mengembangkan sistem ini menjadi aplikasi berbasis web atau seluler. Ini akan membuat proses identifikasi pneumonia lebih mudah dan akan membantu tenaga medis melakukan skrining awal berdasarkan gambar rontgen dada berdasarkan citra Chest X-Ray.

DAFTAR PUSTAKA

- [1] Rio Subandi, Herman, and Anton Yudhana, "Pre-Processing Pada Klasifikasi Citra Medis Pneumonia," *Decode: Jurnal Pendidikan Teknologi Informasi*, vol. 4, no. 1, pp. 86–93, Nov. 2023, doi: 10.51454/decode.v4i1.198.
- [2] M. Ramadhan, D. Iskandar Mulyana, M. Betty Yel, and S. Tinggi Ilmu Komputer Cipta Karya Informatika Jl Raden, "Optimasi Algoritma Cnn Menggunakan Metode Transfer Learning Untuk Klasifikasi Citra X-Ray Paru-Paru Pneumonia Dan Non-Pneumonia," *Jurnal Teknik Informatika Kaputama (JTik)*, vol. 6, no. 2, 2022, doi: <https://doi.org/10.59697/jtik.v6i2.251>.
- [3] M. A. Alghozali, J. R. Triosaputra, and A. Kayan, "Klasifikasi Penyakit Pneumonia Citra Digital X-Ray Menggunakan Metode Convolutional Neural Network dan RGB Equalization," 2024. doi: <https://doi.org/10.29407/stains.v3i1.4290>.
- [4] M. Mujahid, F. Rustam, R. Álvarez, J. Luis Vidal Mazón, I. de la T. Díez, and I. Ashraf, "Pneumonia Classification from X-ray Images with Inception-V3 and Convolutional Neural Network," *Diagnostics*, vol. 12, no. 5, May 2022, doi: 10.3390/diagnostics12051280.
- [5] P. Radočaj, D. Radočaj, and G. Martinović, "Optimizing Convolutional Neural Network Architectures with Optimal Activation Functions for Pediatric Pneumonia Diagnosis Using Chest X-Rays," *Big Data and Cognitive Computing*, vol. 9, no. 2, Feb. 2025, doi: 10.3390/bdcc9020025.
- [6] J. Zhang *et al.*, "Viral Pneumonia Screening on Chest X-Rays Using Confidence-Aware Anomaly Detection," *IEEE Trans. Med. Imaging*, vol. 40, no. 3, pp. 879–890, Mar. 2021, doi: 10.1109/TMI.2020.3040950.
- [7] A. Mabrouk, R. P. D. Redondo, A. Dahou, M. A. Elaziz, and M. Kayed, "Pneumonia Detection on chest X-ray images Using Ensemble of Deep Convolutional Neural Networks," Dec. 2023, doi: 10.3390/app12136448.
- [8] J. Yopento and F. Coastera, "Identifikasi Pneumonia Pada Citra X-Ray Paru-Paru Menggunakan Metode Convolutional Neural Network (CNN) Berdasarkan Ekstraksi Fitur Sobel," 2022. [Online]. Available: <http://ejournal.unib.ac.id/index.php/rekursif/40>
- [9] I. Jawaz and R. Rahmadewi, "Electron : Jurnal Ilmiah Teknik Elektro 138 Sistem Deteksi Pneumonia Paru-Paru dengan Pengolahan Citra Digital dan Machine Learning".
- [10] A. Rachmatullah Pratama and A. F. Cobantoro, "Klasifikasi Citra Pneumonia Menggunakan Arsitektur Convolutional Neural Network (CNN) Pneumonia Image Classification On Using Convolutional Neural Network (CNN) Architecture," 2023. doi: <https://doi.org/10.21107/nero.v8i2.18992>.
- [11] G. M. M. Alshmrani, Q. Ni, R. Jiang, H. Pervaiz, and N. M. Elshennawy, "A deep learning architecture for multi-class lung diseases classification using chest X-ray (CXR) images," *Alexandria Engineering Journal*, vol. 64, pp. 923–935, Feb. 2023, doi: 10.1016/j.aej.2022.10.053.
- [12] W. Akbar *et al.*, "Pneumonia Detection: A Comprehensive Study of Diverse Neural Network Architectures using Chest X-Rays," *International Journal of Applied Mathematics and Computer Science*, vol. 34, no. 4, pp. 679–699, Sep. 2024, doi: 10.61822/amcs-2024-0045.
- [13] S. Dardouri, "Pneumonia Detection in X-Ray Chest Images Based on Convolutional Neural Networks and Data Augmentation Methods," in *International Conference on Information and Communication Technologies for Ageing Well and e-Health, ICT4AWE - Proceedings*, Science and Technology Publications, Lda, 2025, pp. 165–172. doi: 10.5220/0013147300003938.
- [14] M. A. Al-Fahrezi, "Pengaruh Augmentasi Data Terhadap Akurasi Pelatihan Model CNN untuk Klasifikasi Jenis Ikan," *JITSI : Jurnal Ilmiah Teknologi Sistem Informasi*, vol. 6, no. 2, pp. 177–185, Jun. 2025, doi: 10.62527/jitsi.6.2.471.
- [15] E. Evita, "Implementasi Convolutional Neural Network Berbasis Mobilenetv2 Untuk Klasifikasi Pneumonia Menggunakan Citra X-Ray Paru-Paru," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 14, no. 1, Jan. 2026, doi: 10.23960/jitet.v14i1.9088.
- [16] D. Zhang, F. Ren, Y. Li, L. Na, and Y. Ma, "Pneumonia detection from chest x-ray images based on convolutional neural network," *Electronics (Switzerland)*, vol. 10, no. 13, Jul. 2021, doi: 10.3390/electronics10131512.
- [17] R. Kundu, R. Das, Z. W. Geem, G. T. Han, and R. Sarkar, "Pneumonia detection in chest X-ray images using an ensemble of deep learning models," *PLoS One*, vol. 16, no. 9 September, Sep. 2021, doi: 10.1371/journal.pone.0256630.
- [18] A. Guermazi *et al.*, "Improving Radiographic Fracture Recognition Performance and Efficiency Using Artificial Intelligence," *Radiology*, vol. 302, no. 3, pp. 627–636, Mar. 2022, doi: 10.1148/radiol.210937.
- [19] B. Kim, J. S. Lee, and Y. H. Ahn, "Fuzzy based risk assessment for decommissioning concrete bioshield structures in nuclear power plants: Structural risks and worker safety," *Applied Sciences (Switzerland)*, vol. 10, no. 7, Apr. 2020, doi: 10.3390/app10072614.
- [20] I. H. Sarker, "Machine Learning: Algorithms, Real-World Applications and Research Directions," *SN Comput. Sci.*, vol. 2, no. 3, p. 160, May 2021, doi: 10.1007/s42979-021-00592-x.
- [21] C. Janiesch, P. Zschech, and K. Heinrich, "Machine learning and deep learning", doi: 10.1007/s12525-021-00475-2/Published.
- [22] J. Yopento and F. Coastera, "Identifikasi Pneumonia Pada Citra X-Ray Paru-Paru Menggunakan Metode Convolutional Neural Network (CNN) Berdasarkan Ekstraksi Fitur Sobel," 2022. doi: <https://doi.org/10.33369/rekursif.v10i1.17247>.